LDP-V1.5の総合評価 (データ・セマンティクスの理論と実際に関する研究)

AUTHOR(S):

滝沢, 誠; 横塚, 実

CITATION:

滝沢, 誠 ...[et al]. LDP-V1.5の総合評価 (データ・セマンティクスの理論と実際に関する研究). 数理解析研究所講究録 1982, 461: 127-150

ISSUE DATE:

1982-06

URL:

http://hdl.handle.net/2433/103135

数理解析研究所講究録
461巻 1982年 127-150

ＬＤＰ－Ｖ１．５の総合評価

滝沢　誠　横塚　実

財団法人日本情報処理開発協会

１．序

ローカルデータベースプロセッサ（ＬＤＰ－Ｖ１．５）〔ＴＡＫＩＭ80, 82ａ, ｂ〕は，ＣＯＤＡＳＹＬデータベースシステム上の検索利用関係インタフェースシステムである。本システムは，異種分散型データベースシステムＪＤＤＢＳ〔ＴＡＫＩＭ78, 79, 80, 82ａ, ｂ〕の異種データベースシステムとしてのＣＯＤＡＳＹＬデータベースシステムに対する一般ユーザ向けの共通非手続的検索利用インタフェースとともに，ＣＯＢＯＬ　ＤＭＬプログラムの開発支援システムとなる。本システムは，当協会のＭ－１７０ＦのＡＩＭ，Ａｃｏｓ－７００のＡＤＢＳ上で1981年初めより既に実働している。

本論文では，ＬＤＰ－Ｖ１．５の有効性と有用性を示すために，ＬＤＰ－Ｖ１．５の性能面からと利用面からの総合的な評価について述べる。２章ではＬＤＰ－Ｖ１．５の概要を述べ，３章では性能評価を，４章では利用面からの評価について述べる。本評価によって，種々のＱＵＥＬ問合せに対して数秒～数１０秒の経過時間によって，人間が作れば数時間以上要するＣＯＢＯＬ　ＤＭＬプログラムを生成できると共に，これを実行させ結果を自動的に得れることが明らかになった。

２．ＬＤＰ－Ｖ１．５の概要

ＬＤＰ－Ｖ１．５　は，以下の機能を有している〔ＴＡＫＩＭ80, 81, 82ａ〕。

（１）　ＣＯＤＡＳＹＬスキーマから，検索用の関係スキーマ（ＬＣＳ）の生成

（２）　ＱＵＥＬ問合せからＣＯＢＯＬ　ＤＭＬ　プログラムの生成

（３）　生成されたＣＯＢＯＬ　ＤＭＬ　プログラムの実行

（４）　実行結果を関係としてユーザに出力

（５）　ＬＣＳに対するビューの階層的定義と検索演算サポート

2．1　スキーマ変換

ＣＯＤＡＳＹＬスキーマ（ローカル内部スキーマ（ＬＩＳ））から，関係スキーマ（ローカル概念スキーマ（ＬＣＳ））は，次の様にして生成される〔ＴＡＫＩＭ81〕。

（1）　レコード型Ｒ（ｔ1，・・・，ｔn）に対して，関係スキーマＥ（Ｒ）（ @Ｅ（Ｒ），ａ（ｔ1），・・・，ａ（ｔn））が生成される。このＥ（Ｒ）は，レコード型Ｒに対応した関係名であり，ａ（ｔｉ）はｔｉの属性名である。@Ｅ（Ｒ）は，Ｒのｄｂキーを値として取る仮想属性で主属性と呼ばれる。関係Ｅ（Ｒ）内の組は，Ｒのレコード実現値に１対１に対応する。Ｅ（Ｒ）の組は，@Ｅ（Ｒ）の値，即ち，対応する実現値のｄｂキーによって識別される。@Ｅ（Ｒ）は，Ｅ（Ｒ）の主キーともなる。関係Ｅ（Ｒ）をＥ関係と呼ぶ。

（2）　親レコード型をＡ，子レコード型をＢとするセット型Ｓに対して，関係スキームＲ（Ｓ）（@Ｅ（Ａ），@Ｅ（Ｂ））が生成される。ここでＲ（Ｓ）は，セット型Ｓに対応した関係名である。@Ｅ（Ａ）と@Ｅ（Ｂ）は，各々レコード型ＡとＢから生成された関係スキームＥ（Ａ）とＥ（Ｂ）の主属性である〔図２．１〕。@Ｅ（Ｂ）は，主キーともなる。

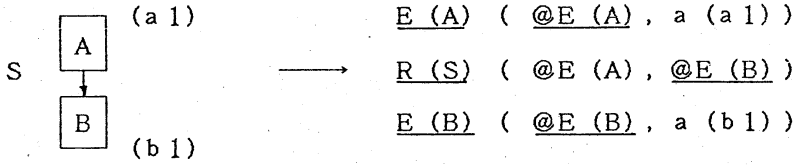

図２．１　　セット型

（3）　図２．２の様なｎ個のレコード型Ｒ１，・・・，Ｒｎ間の関係性を表すレコード型（リンクレコード型と呼ぶ）に対しては，関係スキームＲ（Ｌ）（ @Ｅ（Ｒ１），・・・，@Ｅ（Ｒｎ），ａ（ｔ１），・・・，ａ（ｔｎ））が生成される。

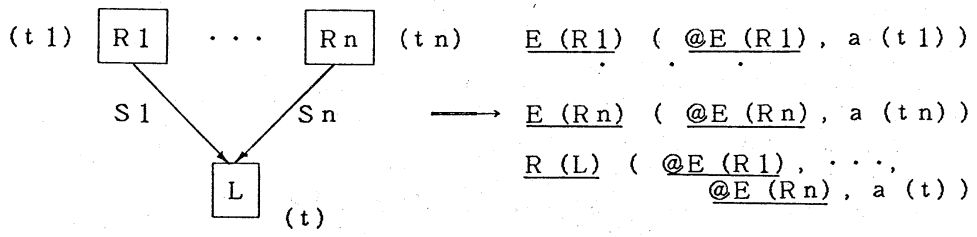

図　２．２　リンクレコード型

図2．3の様にＲｉ＝Ｒｊ＝Ｒの時には，Ｒ（Ｌ）の主属性がＳｉ@Ｅ（Ｒ），Ｓｊ@Ｅ（Ｒ）となる。

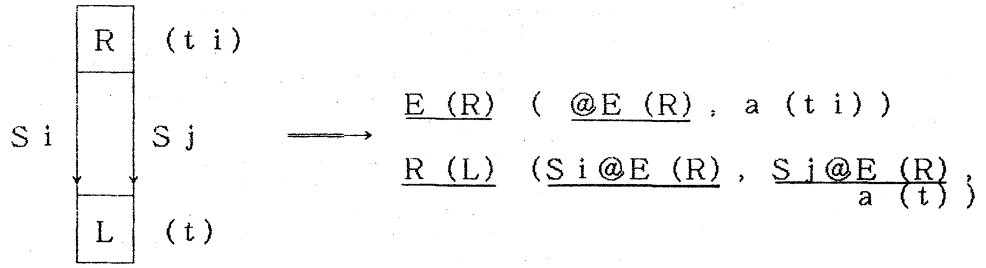

図　2．3　リンクレコード型

図2．4のＣＯＤＡＳＹＬスキーマ（ＬＩＳ）から生成される関係ＬＣＳは，図2．5の様になる。ここで簡単にする為にａ（ｔｉ）＝ｔｉ，Ｅ（Ｒ）＝Ｒ，Ｒ（Ｓ）＝Ｓ，Ｒ（Ｌ）＝Ｌとする。

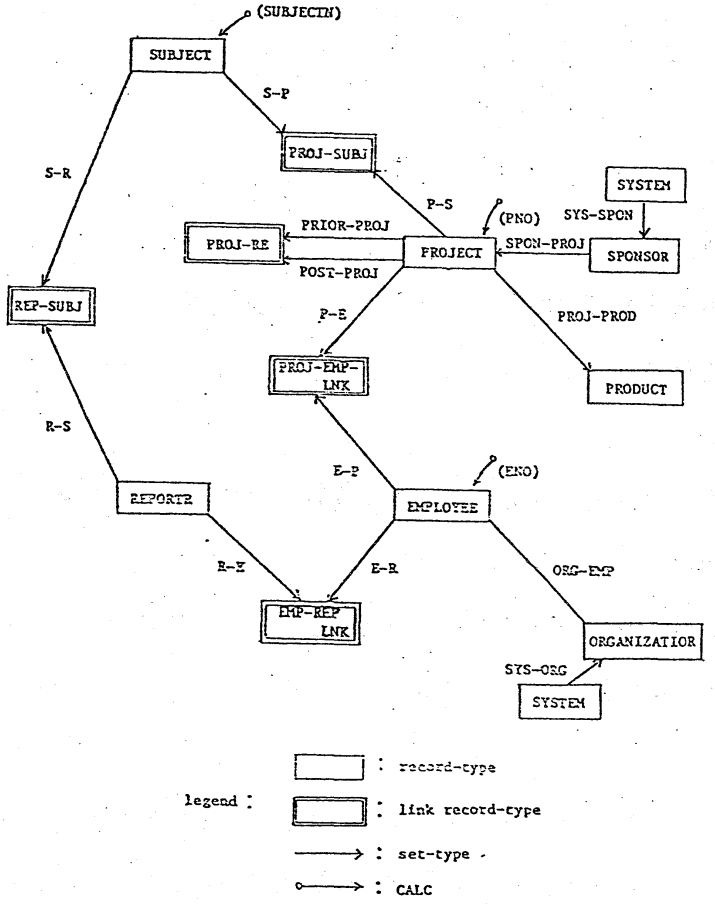

図　2．4　ＰＲＤＢＳのスキーマ

```
ESR  SUBJECT     (@J, subjectn)
     SPONSOR     (@SPONSOR, sname, stype)
     PROJECT     (@P, pno, pname, proj-type,
                  status-f, syear, eyear, budget)
     PRODUCT     (@PRODUCT, pd-no, pd-name, ptype,
                  cost, year, language, psize)
     EMPLOYEE    (@E, eno, ename, efname, esex,
                  birth-place, birth-year,
                  birth-month, alma-mater, major,
                  degree, deg-year, hired-year,
                  retiered-year, dept, position,
                  tel, ext)
     REPORTR     (@R, rno, title, source-n, vol,
                  numb, month, year, from-page,
                  to-page, total-page,
                  no-of-author, language,
                  written-year, cost, rtype,
                  rstate)
     ORGANIZATIOR (@ORGANIZATIOR, org-name,
                   org-type)

RSR  SPON-PROJ   (@SPONSOR, @P)
     PROJ-PROD   (@P, @PRODUCT)
     PROJ-EMP-LNK (@P, @E, smonth, eyear,
                   emonth, pposition, role,
                   percentage)
     PROJ-SUBJ   (@P, @J)
     REP-SUBJ    (@R, @J)
     EMP-REP-LNK (@R, @E, auth-no)
     PROJ-RE     (@P, PRIOR-PR-@P)
     ORG-EMP     (@ORGANIZATIOR, @E)
```

図　2．5　PRDBSのLCS

2．2　問合せ変換

問合せ変換〔TAKIM80, 82b〕とは，QUEL問合せから，COBOL　DMLを生成し，実行させ結果を得ることである。QUELとCOBOL　DMLプログラムは，次の2点が各々異なっている。

（1）参照するデータ構造　リレーショナル構造　CODASYL構造

（2）アクセス単位　　非手続的と手続的

この為に，QUEL問合せの意味を，CODASYLデータ構造によって，述語計算に基づいた非手続的表現を導入した。これを，CODASYL問合せグラフ（CQG）と呼ぶ。問合せ変換は，次の2つのステップから成る。

（i）構造変換　QUEL問合せからCODASYL問合せグラフ（CQG）を生成することによって（1）の問題を解決する。

（ii）アクセスパス生成　CQGからアクセス手順を生成し，（2）の問題を解決する。

2．2．1 構造変換

図2．5に対する『プロジェクトの開始以前に雇用されたメンバが，第一著者である論文の主題と，そのプロジェクトの主題が異なっている論文とそのプロジェクトの番号を求めよ。』は，ＱＵＥＬで図2．6の様に表せる。この問合せは，図2．7の様なグラフで表すことが出来る。これを，ＬＣＳ問合せグラフ（ＬＱＧ）と呼ぶ。

```
RANGE (E, EMPLOYEE) (P, PROJECT) (R, REPORTR) ;
RANGE (J, SUBJECT) ;
RANGE (PJ, PROJ-SUBJ) (RJ, REP-SUBJ) ;
RANGE (PE, PROJ-EMP-LNK) (ER, EMP-REP-LNK) ;
RETRIEVE INTO ANTI010 (P. PNO, R. RNO)
WHERE
P. @P=PE. @P   AND   PE. @E=E. @E   AND
E. @E=ER. @E   AND
ER. @R=R. @R   AND   R. @R=RJ. @R   AND
P. @P=PJ. @P   AND   PJ. @J=J. @J   AND
J. @J NE RJ. @J   AND
P. SYEAR GE E. HIRED-YEAR   AND
ER. AUTH-NO=1 ;
```

図2．6　　問合せ例

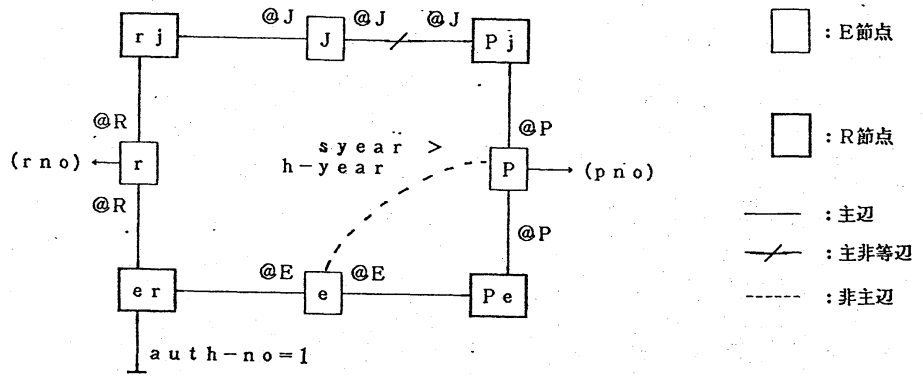

図2．7　　ＬＱＧ

ＬＱＧ節点は，組変数を表し，節点間の辺は結合を表す。主属性間の結合としては，＝と≠のみが許される。2．1で述べた様に，主属性が値として，組の識別子（即ち，ｄｂキー）を取る為に，＜，≦，≧，＞の比較は意味がないからである。実線は主辺と呼ばれ，主属性間の等結合を表し，≠は非等（≠）結合を表し，主非等辺と呼ばれる。点線は，主属性以外の通常の属性間結合を示し，非主辺と呼ばれる。⊣は制限式を，⟶は目標属性を示す。ＬＱＧ内の

辺と節点の表す条件式の積が問合せの条件になっている。

ＬＱＧから，表２．１に従って変換されたグラフが，ＣＯＤＡＳＹＬ問合せグラフ（ＣＱＧ）である〔図２．８〕。ＣＱＧ節点は，実現値変数を示している。節点間の辺は，セット型を示している。変換は，Ｅ関係の節点を，対応するレコード型の実現値変数に変え，節点間の辺を表２．１に基づいて対応するセット型に変えることによってなされる。２つのＣＱＧ節点ｘとｙの間のセット辺Ｓは，ｘとｙが表す実現値が同一のセット実現値内に属さねばならない条件を表している。ＣＱＧの辺と節点の表す条件式の積は，ＬＱＧに於けるものと等価である。ＣＱＧは，ＱＵＥＬ問合せ〔図２．６〕の意味を，ＣＯＤＡＳＹＬデータ構造によって，非手続的に 表したものである。

表２．１　　ＬＱＧとＣＱＧの対応表

1) Yはセット型

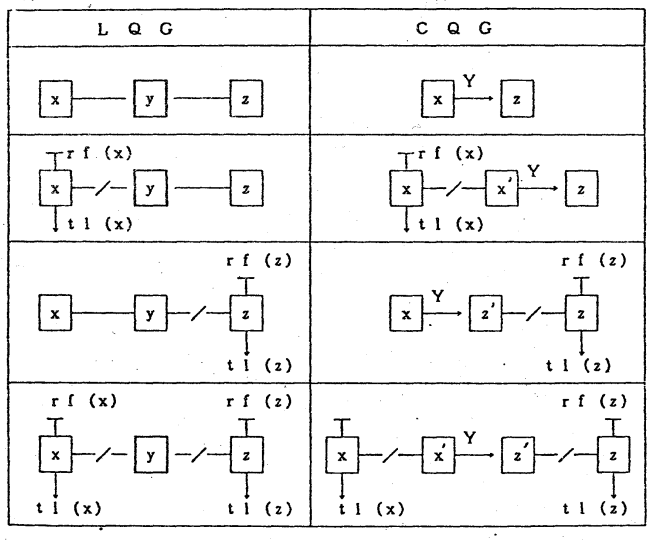

2) Yはリンクレコード型

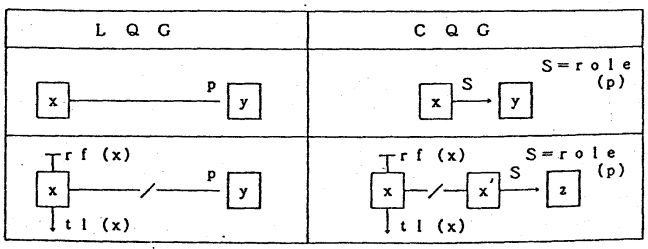

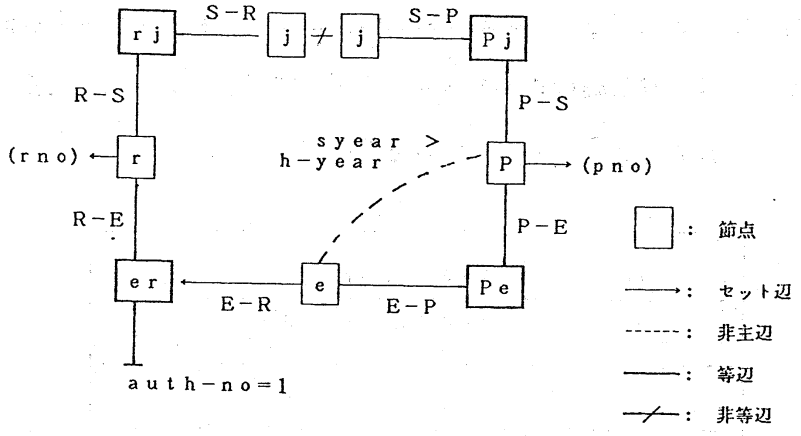

図2．8　　CQG

2．2．1　アクセスパス生成

アクセスパスは，ＣＱＧのセット型を表す辺を縦型に，サーチすることによって得れるアクセス木によって表される。アクセス木は，アクセスされる実現値数がなるべく少なくなる様に生成される。アクセス木生成で，可能な辺が複数存在する時，次の辺は，選択度，結合度といった統計情報を用いたアクセスされる実現値数見積りに基づいて決定される。

A．　結合度

親をA，子をBとするセット型Sに対して，結合度ｃｎｔ（S）とｉｃｎｔ（S）とを次の様に定義する。

ｃｎｔ（S）＝　Aの各実現値が，Sの子として持つB実現値の平均数

ｉｃｎｔ（S）＝　Bの各実現値が，Sの親としてA実現値を持つ確率

アクセス木の枝ｌ〔図2．9〕に対して，

ｃｎｔ　（S）　　ｉｆ　xはSの親

ｃｔｌ＝｛

ｉｃｎｔ（S）　　ｏｔｈｅｒｗｉｓｅ

Sは，枝ｌの表すセット型である。

B.　選択度

節点aに対して，ｓｔａを，aに関する制限式によって制限される実現値の割合，即ち選択度とする。ｓｔａは，制限論理式ｒｆ（a）によって表2．2の様に定義される。

表2．2　ｒｆ（a）の選択度

ｒｆ　(a)	選択度　ｓｔ（ｒｆ（a））
r．a＝v	card (a)／card (r) (＝ｓｔｒａと記す)
r．a≠v	1 －ｓｔｒａ
r．a $\begin{cases} > \\ < \end{cases}$ v	(1－ｓｔｒａ)／2
r．a $\begin{cases} \geq \\ \leq \end{cases}$ v	(1＋ｓｔｒａ)／2
r．a＝v1∨・・ ∨r．a＝vn	n．ｓｔｒａ
ｒｆ1∧・・∧ｒｆn	ｓｔｆ1・ｓｔｆ2・・ｓｔｆn ここでｓｔｆｉ＝ｒｆ1の選択度
ｒｆ1∨・・∨1ｆn （ｒｆｉは互いに異なった属性を参照している）	1－(1－ｓｔｆ1)・・(1－ｓｔｆn)

C.　発見法

パスとして可能な候補がある場合，次の様な発見法を用いて，次の辺を選択する。発見法としては，1レベルのサーチ，2レベルのサーチ，3レベルのサーチの3種を考えた。各サーチレベルの深さにより，それぞれ次の評価関数を用いて，各評価関数ａｃｃｉの値を最少とする辺1をxの次の辺として選択する。

$$acc1(x, l, y) = ctl$$

$$acc2(x, l, y) = ctl \cdot (1 + sty \cdot \min_{(m)}(ctm))$$

$$acc3(x, l, y) = ctl \cdot (1 + sty \cdot \min_{(m)}[ctm \cdot (1 + stz \cdot \min_{(n)}(ctn))])$$

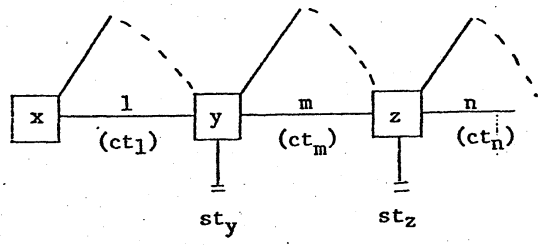

図2．9　アクセス木

3．　性　　能　　評　　価

本章では，ＬＤＰ－Ｖ１．５の性能面からの評価について述べる。性能評価は，以下の点を目標にしている。

（1）ＬＤＰ－Ｖ１．５の各構成モヂュールの負荷を明らかにする。これから，性能面での隘路を求め，改良を行う。

（2）アクセスパス生成の負荷と，それによって生成されたＣＯＢＯＬ　ＤＭＬプログラムのアクセス効率を明らかにする。

（3）選択度，結合度といった統計情報の正しさの検証を行う。

3．1　評　　価　　環　　境

ＬＤＰ－Ｖ１．５を，以下の環境下で評価する。

（1）ＬＤＰ－Ｖ１．５を，Ｍ－１７０Ｆ上で実働させる。Ａｃｏｓ－７００に対しては，Ｍ－１７０Ｆ上のＬＤＰ－Ｖ１．５で生成されたＣＯＢＯＬ　ＤＭＬプログラムをＡＤＢＳ上で動かす。

（2）ＬＤＰ－Ｖ１．５を単一利用者の下で実働させ，その経過時間（ｅｌａｐｓｅ　ｔｉｍｅ）を測定する。親言語の時間取得機能（ｃａｌｌ　ＣＰＴＩＭＥ）で得た経過時間は，Ｍ－１７０Ｆでは10%から20%の誤差があるが，今回は各評価問合せに対して各一回実行させる事とした。

（3）評価用のデータベースとしては，図２．４で示したプロジェクトデータベースシステム

（ＰＲＤＢＳ）を用いる。ＰＲＤＢＳ内の各レコード型，セット型，リンクレコード型の実現値数とサイズを表３．１に示す。

表３．１　ＰＲＤＢＳの実現値情報

関係性名	タイプ	実現値数
ＳＹＳ－ＯＲＧ	セット	1
ＳＹＳ－ＥＭＰ		1
ＳＹＳ－ＳＰＯＮ		1
ＯＲＧ－ＥＭＰ		15
ＳＰＯＮ－ＰＲＯＪ		4
ＰＲＯＪ－ＰＲＯＤ		9
Ｅ－Ｐ	リンク	62
Ｐ－Ｅ		62
Ｅ－Ｒ		155
Ｒ－Ｅ		155
Ｒ－Ｓ		625
Ｓ－Ｒ		625
Ｐ－Ｓ		201
Ｓ－Ｐ		201
ＰＲＩＯＲ－ＰＲＯＪ		5
ＰＯＳＴ－ＰＲＯＪ		5

レコード型	実現値数
ＥＭＰＬＯＹＥＥ	68
ＯＲＧＡＮＩＺＡＴＩＯＲ	15
ＰＲＯＤＵＣＴ	9
ＳＵＢＪＥＣＴ	136
ＰＲＯＪＥＣＴ	14
ＲＥＰＯＲＴＲ	84
ＳＰＯＮＳＯＲ	4

３．２　各構成モヂュールの負荷

図３．１に，２章で述べた各構成モヂュールの負荷を，各々の経過時間で示す。図から分る様にＤＭＬＧでのＣＯＢＯＬ　ＤＭＬプログラムを文字列として生成する為に全経過時間の70％から90％が費やされてしまう。アクセスパス生成の為の経過時間の割合は高々数％にしか過ぎない。又，ＱＵＥＬ問合せから内部表現としての木，グラフの生成と操作の為に10％から20％が費やされている。

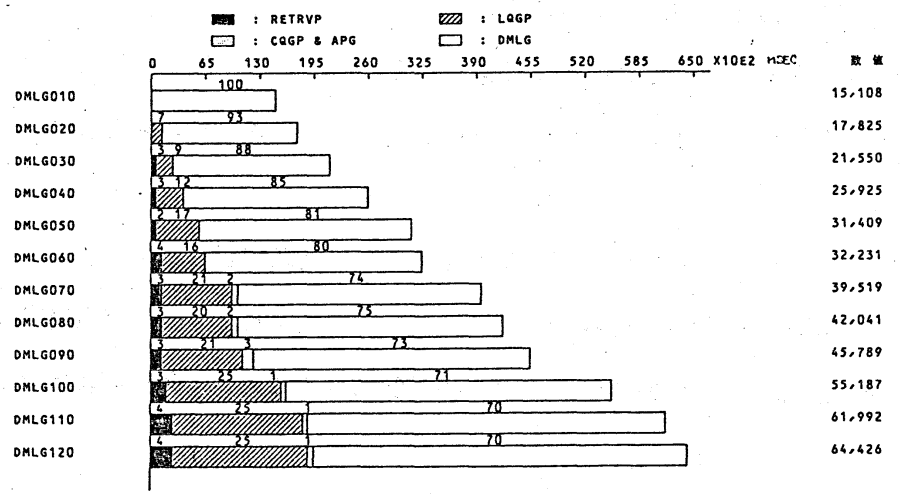

図３．１　各構成モヂュールの負荷

ＬＤＰの性能を向上させる為に，ＤＭＬＧの改良を行った。ＤＭＬＧでは，ＤＭＬの文字パターンを一文字ずつ左から右にサーチして，パラメータを見付けて，その置換を行っている。

例　ｆｉｎｄ　ｎｅｘｔ　＄01　ｗｉｔｈｉｎ　＄02.

→　ｆｉｎｄ　ｎｅｘｔ　EMPLOYEE　ｗｉｔｈｉｎ　ORG－EMP.

この為に，以下の改良を行った。

（ｉ）パラメータを左づめする。

（ii）これより変換の不要となる右端を明示する。

（iii）コメント文を除去する。

これによって，図３．２に示す様にＤＭＬＧの経過時間を30％から40％短縮できた。

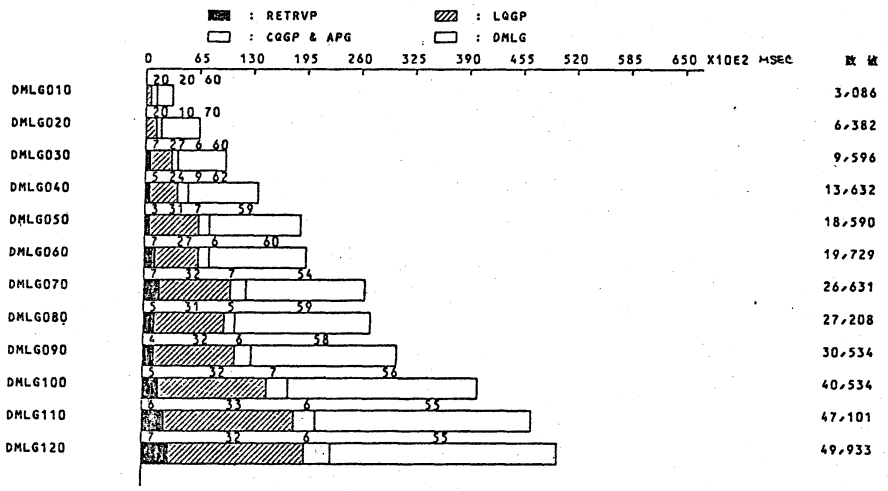

図３．２　改良後の各構成モヂュールの負荷

３．３　ア　ク　セ　ス　パ　ス　生　成　の　負　荷

アクセスパスは，ＤＦＡ１，２，３の三種の発見法によって，ＣＯＤＡＳＹＬ問合せグラフ（ＣＱＧ）から生成される。アクセスパス生成に必要な経過時間を，ＣＱＧの辺数に対して，プロットしたものが図３．３である。

ＤＦＡ１は，一レベルのサーチを行う発見法である。図から分る様にほぼ線形に経過時間が増加している事が分る。ＤＦＡ２もほぼ線形に経過時間が増加している。一方ＤＦＡ３は，辺数に対して，二乗のオーダで経過時間が増加している。

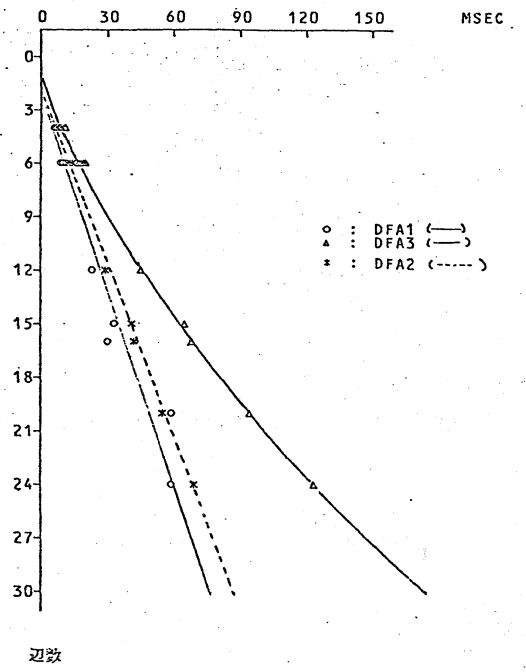

図3．3　アクセスパス生成の負荷

3．4 アクセスパス生成

アクセスパスは，生成されたCOBOL　DMLプログラムの全経過時間を短縮する為に，アクセスされるレコード型の実現値の期待値が最少となる様に，選択度，結合度といった統計情報を基にして生成される。ここでは，COBOL　DMLプログラムの経過時間がアクセスされる実現値数に単調増加するものと仮定している。図3．4は，種々の問合せから生成されるCOBOL　DMLプログラムについて，実際にアクセスされた実現値数と経過時間との関係を示している。図から分る様に，この仮定が正しい事が分る。

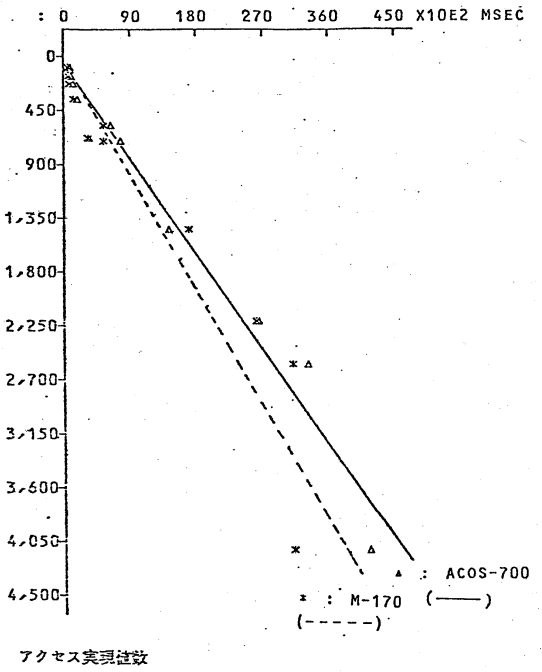

図３．４　アクセスされた実現値数と経過時間

アクセスパスは，選択度，結合度といった統計情報を基にして，２章で述べた様なコスト関数に基づいて見積られる。我々の用意した８個の問合せについて，見積りと，実際にアクセスされた実現値数とを表３．２に示す。この例では，見積りと実際の値との間に，あまり相関がみられない。

表３．２　実現値数の見積りと実際

Query #	No. of Node	No. of Join	DFA1		DFA2		DFA3	
			Est.	Act.	Est.	Act.	Est.	Act.
10	5	4	107	231	107	231	107	231
20	7	6	158	6981	158	6981	158	6981
30	5	4	31	92	31	92	31	92
40	12	12	194	954	267	993	306	2281
50	15	16	503	19267	503	34672	889	18681
60	21	24	3163	22839	3163	51251	5875	33747
70	14	15	577	4932	396	2411	396	1791
80	18	20	577	4932	549	2411	54	12090

統計情報が，データベース全体の実現値についての平均値であるのに対して，個々の問合せは，データベースの一部のみをアクセスする。このアクセスされる部分の値分布が均一でない為に，この様な現象が生じたと考えられる。従って，

（ｉ）一般に，データベース全体の値分布は，各アプリケーションのアクセスする値分布と一致しない。

（ii）各アプリケーションのアクセスするデータベースの範囲は，比較的限られている。

これらの事より，見積りと実際の実現値数との関連を密接にする為に，以下の様な方法を用いる。

（ｉ）統計情報をアプリケーション毎に備える。データベース内で，アプリケーションがアクセスする部分についての実現値の統計情報を用意する。

（ii）結合度をより現実と適合させる為に，次の様な動的なチューニング方法を用いる。Ｓをセット型とする。ｃｎｔ（Ｓ），ｉｃｎｔ（Ｓ）を各々Ｓの正，逆結合度とする。あるアプリケーションプログラムの実行について，ｏｃｎｔ（Ｓ）とｍｃｎｔ（Ｓ）を，各々Ｓの親から子にアクセスした時の親と子のアクセスされた実現値の総数とする。ｏｉｃｎｔ（Ｓ）とｍｉｃｎｔ（Ｓ）を各々，子から親をアクセスした時の子及び親のアクセスされた実現値の総数とする。

$$cnt(S) \leftarrow \text{if } mcnt(S) \neq 0, \text{ then } [\, cnt(S) + (\, ocnt(S) / mcnt(S)\,)\,] / 2$$

$$icnt(S) \leftarrow \text{if } micnt(S) \neq 0, \text{ then } [\, icnt(S) + (micnt(S) / oicnt(S)\,)\,] / 2$$

図３．５は，動的チューニングによる見積りの改良を示している。

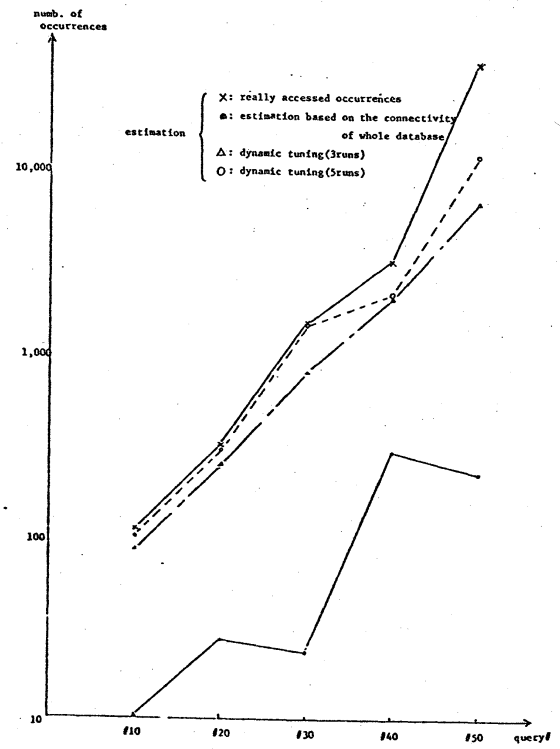

図３．５　動的チューニングによる見積りの改良

図より，動的チューニングによって，結合度を現実の状態に近付ける事ができる事が分る。

図３．６は，制限式を含んだ場合を示している。データベース全体の統計情報による見積りよりも，実際に近付いているが，図３．４ほどではない。これは，選択度がアクセスされたデータベースの範囲の情況を反映していない事によっている。ＣＯＤＡＳＹＬデータベースシステムの選択度としては以下の点を考慮する必要がある。

（１）レコード型の各項目の値毎に，この値を持つ実現値数を保持せねばならない。

（２）レコード型全体と共に，各セット実現値内での子レコード実現値の値分布が必要になる。

（３）等制限式は，（１）及び（２）によって正しく求められるが，不等制限式（<，≦，≧，>）に対する選択度を正しく求めるには，完全な値の分布が必要になる。

この為の情報を全て異種情報に持たすには，第１に格納空間の大きさが問題になる。（１）については，１つの方法は，よく用いる値に対してのみ情報を保つことである。しかし，（２）

については，アクセスコストの見積りの時点でセット実現値内での制限式の選択度を，反映させることは出来ない。何故なら，あるセット型でアクセスされる子実現値は，実際にアクセスされて，はじめてわかるからである。

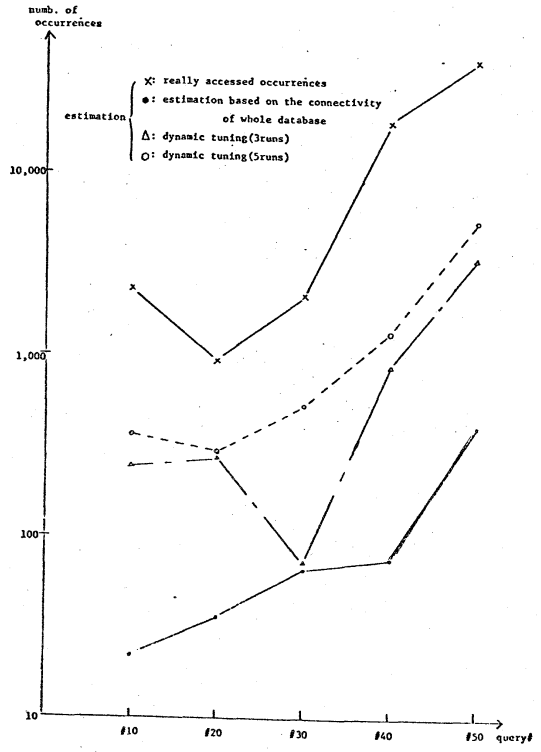

図３．６　制限式を持った問合せに対する見積り

アクセスパスを見付ける為のサーチレベルの深さと，その効果について考える。ここでは，動的チューニングによって，統計情報が，実際の状態に合う様になっているとする。表３．３は，この時の３つの方法ＤＦＡ１，２，３の見積り数と，実際のアクセス実現値数を示している。表から分る様に，サーチレベルを深めても，あまり効果はない。

表　3．3　サーチレベルと効果

Query #	No. of Node	No. of Join	DFA1		DFA2		DFA3	
			Est.	Act.	Est.	Act.	Est.	Act.
10	5	4	110	117	110	117	110	117
20	7	6	142	151	142	151	142	151
30	8	8	1903	2215	1903	2215	1903	2215
40	11	11	3799	1194	3799	1199	3801	1199
50	12	12	2318	3593	425	7585	3076	3335
60	13	14	3270	4697	6358	3343	6358	3343
70	14	15	8328	2623	5321	7656	5340	6190
80	18	20	824	3135	1563	1573	2423	8093

3．5　COBOL　DMLプログラム

生成されたCOBOL　DMLプログラムの実行結果について考える。COBOL　DMLプログラムは，アクセスされるレコード型とセット型の数（CQGのノード数とセット型の数）に対して，表3．4に示す様なプログラム文数となる。

表3．4　プログラム文数

QUERY #	NO. OF NODES	NO. OF JOIN	NO. OF COBOL STEPS		
			DATA DIV.	PROC. DIV.	TOTAL
R1	5	4	103	358	461
R2	8	8	112	426	538
R3	7	6	112	384	496
R4	16	15	137	594	731
R5	12	12	123	530	653

COBOL　DMLプログラムの実行は，次の3部分から成る。

（1）　初期化と終了

（2）　実現値の巡航

（3）　出力処理

これらをまとめると表3．5の様になる。表から分る様に，初期化／終了の為の経過時間は，

ほぼ同一で次の様である。

表3．5　COBOL　DMLプログラムの経過時間

QUERY #	DBMS	COBOL ELAPSE TIME(MSEC) INIT/END	NAVIGATION	OUTPUT
10	AIM	610	7220	250
	ADBS	7210	3730	430
20	AIM	640	195950	5860
	ADBS	6890	195840	37400
30	AIM	650	411240	13630
	ADBS	6750	618180	95850
40	AIM	650	45480	1200
	ADBS	6670	43350	8120
50	AIM	670	62940	1760
	ADBS	6660	10100	1800

AIM　　～650〔ms〕

ADBS　　～6800〔ms〕

4．　利用性評価

次に，LDP－V1．5のユーザから見た有用性について評価する。これは，以下の2つの場合の全ライフサイクルの経過時間を測定し，前者の有用性を経過時間として定量化する事を行う。

（1）　QUELによって問題を記述し，これをLDP－V1．5でCOBOL　DMLプログラム変換し実行させ，結果を得る。

（2）　同一の問題に対して，COBOL　DMLを用いて，設計し，コーディングし，デバッグして，結果を得る。

4．1　評価方法

評価を次の様にして行う。

（1）同一の日本語の問題に対して，以下を行う。

（i）計算機の素人によって，LCSに基づいて問題をQUELで記述する。

(ii) COBOLエキスパート（経験10年）によって，CODASYLスキーマに基づいて，問題をCOBOL DMLで記述する。

(2) M－170FのAIM上のPRDBSを用いる。

(3) QUEL及びCOBOL DMLによる問題解決のライフサイクルの各ステップの経過時間を測定する。〔図4．1〕

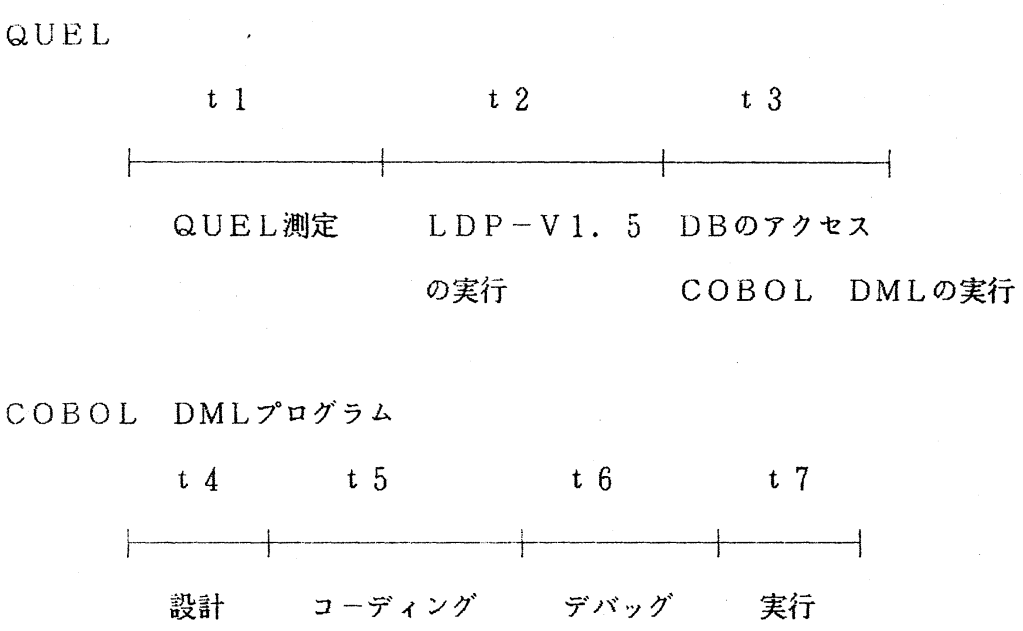

図 4．1 ライフサイクル

4．2 問題

問合せ問題を，以下に示す。

R1 各projectのメンバの書いたレポートの中で，このメンバが第一著者（auth－no＝1）であるレポートの番号（rno）とそのprojectの番号（pno）とを求めよ。

R2 projectのテーマと同じテーマの論文を書いているprojectのメンバの番号（eno）と，その論文番号（rno）を求めよ。

R3 distributed database systems又は，computer

networks，又はlocal networks，又は，database systems，又はdata modelsを研究しているprojectのメンバの中で，Jipdecに属し，かつ1970年以降に入社（hired year）したメンバの名前（ename），番号（eno），及びそのproject番号を求めよ。

R4 distributed database systemsと，database systemsと，four-schema structureと，query translationを研究しているprojectのメンバが書いたレポートの主題（subjectn）と，そのメンバの所属（org-name）及び，メンバの番号を求めよ。

R5 projectのメンバの中で，projectのテーマと同一のテーマの論文を書いているメンバの名前と，そのメンバが属している全てのproject番号及び，このメンバが第一著者である全ての論文の番号を求めよ。

4．3 評価結果

表4．1に，測定結果を示す。

表4．1 利用性評価結果

QUERY #	NO. OF RECORD TYPES	NO. OF SET TYPES		DESIGN CODING DEBUG	LDP ELAPSE TIME	NO. OF COBOL STEPS	NO. OF ACCESS OCCU.	COBOL ELAPSE TIME
R1	5	4	Q	4.5(M)	10(S)	461	335	4.5(S)
			C	10 (H)		104	335	3.5(S)
R2	8	8	Q	5.3(M)	16(S)	538	9748	140 (S)
			C	10 (H)		334	4150	65 (S)
R3	7	6	Q	11 (M)	12(S)	496	561	5.1(S)
			C	10 (H)		117	205	3.5(S)
R4	16	15	Q	14 (M)	22(S)	731	1831	27.7(S)
			C	17 (H)		256	1209	17 (S)
R5	12	12	Q	8 (M)	18(S)	653	59709	516 (S)
			C	15 (H)		284	1025	18 (S)

C=COBOL，Q=QUEL，(H)=HOUR，(M)=MINUTE，(S)=SECOND

表から分る様，LDPでは，数分から数10分で結果を得れる。しかし，COBOLによっては，

結果を得るまでにエキスパートでも数時間から数10時間を要してしまう。この意味で，ＣＯＤＡＳＹＬデータベースシステム上に，非手続的な検索インタフェースを設ける事は，ソフトウェアの生産性の点から優れていることが分る。

アクセスパス生成では，簡単な問題に対して，ＬＤＰはエキスパート同様なアクセスパスを生成できるが，複雑な問題に対しては，エキスパートのものより劣っていることが分る。又，ＬＤＰによって生成されるＣＯＢＯＬ　ＤＭＬプログラムの量でもエキスパートより数倍多くなっている。

アクセスパス生成でエキスパートとＬＤＰとの差は，特にＣＱＧがループを含む問合せにおいて，アクセス方法が異なる。ＬＤＰは，なるべく途中で中間結果を生成せずに一連の巡航アクセスによって結果を得ようとする。この為，合流節点等に於ける現在子の保持方法に注意を払っている。しかし，エキスパートは，むしろループを分割して中間結果を生成し，これを最後にまとめて処理しようとしている。

５．　まとめと今後の課題

本論文では，ＣＯＤＡＳＹＬデータベースシステム上の非手続的な関係インタフェースシステム，ローカルデータベースプロセッサＬＤＰ－Ｖ１．５の性能及び利用面からの総合的な評価について述べた。

ＬＤＰ－Ｖ１．５は，現在，当協会のＭ－１７０ＦのＡＩＭ及びＡｃｏｓ－７００のＡＤＢＳ上に，ＰＬ／Ｉによって実現されている。ＬＤＰ－Ｖ１．５は，ＰＬ／Ｉソース文数約１０000，オブジェクトサイズ２５０ｋＢである。

性能面の評価では，まずＬＤＰ－Ｖ１．５の各構成モヂュールの負荷を経過時間によって測定し，隘路となるモヂュールを明らかにした。隘路となるモヂュールは，ＣＯＢＯＬ　ＤＭＬプログラム文字列の生成を行うＤＭＬＧであり，全経過時間の過半数を占めていた。これの改良によって，全体に，20%～30%経過時間を短縮出来た。アクセスパス生成は全体の高々数%の負荷であり，ＬＤＰ全体から見ると無視し得る程度である。現在，ＤＭＬＧと共，ＱＵＥＬ問合せからＣＯＤＡＳＹＬ問合せグラフ（ＣＱＧ）を作るまでの負荷が大きな重みを占めている。ここでは，木，グラフ等の構造の非手続的な操作が行われるからである。

我々は，選択度，結合度といった統計情報によって，アクセスコストを見積り，その見積りをなるべく少なくする様にアクセスパスの生成を行っている。ここでの評価の目的は，次の3点の明確化である。

（1） アクセスコストとして，アクセスされる実現値数とすることの妥当性

（2） 選択度，結合度といった統計情報を用いた見積りの正しさ

（3） サーチレベルを深めることによるＬＤＰの負荷の増大と，その効果を明らかにする。

ＣＯＢＯＬプログラム実行の中で，実現値を巡航する経過時間は，アクセスされる実現値数に単調増加する事が明らかになった。従ってアクセスされる実現値数を最少化する事によって，ＣＯＢＯＬ　ＤＭＬプログラムの実行経過時間を短縮できる。

（2）では，データベース全体の平均値としての統計情報による見積りと，例で用いた問合せを実行した結果とはよく適合しない。この解決方法として次の２つの方法を用いた。

（ｉ） アプリケーション毎にこれらが用いる実現値についての統計情報を用意する。

（ii） この統計情報の結合度情報については，各実行結果を反映させる動的チューニング方法によってアプリケーションがアクセスされる実現値の統計情報を反映させる。

これによって，見積りを，実際の値に近付けることができた。しかし，選択度の動的チューニング方法を行う為には，各属性の値毎にこの値を有する実現値数を記憶させると共にセット実現値毎の分布情報も同時に持たせねばならない。これは，格納負荷の増大をもたらしてしまう。又，スキーマレベルでのアクセスコストの見積りは，この情報を反映させる方法がない。しかし，動的チューニングは，更新が起るデータベースにおいて有効である。１つの実行によって更新効果を統計情報に反映できるからである。

サーチレベルを深めて，動的チューニングを行った結果では一般によりよいアクセスパスを生成できることは明らかではない。

問合せの結果属性には，ＣＯＤＡＳＹＬスキーマの構造に対応して一般に１対Ｎ，あるいはＮ対Ｍの関係性が存在する。この為，アクセスする実現値数だけでなく検索結果の出力量を最少化することが必要である。

ＬＤＰ－Ｖ１．５の有用性では，同一の問題に対して，ＱＵＥＬによって記述しＬＤＰで結果を得る方法と，ＣＯＢＯＬでプログラムを組み，実行する方法とを全経過時間について比較

した。この結果，ＬＤＰでは，数分～数10分で結果を得れるのに対してＣＯＢＯＬでは数時間～数10時間を要してしまう。従って，ソフトウェアの全生産性では，ＬＤＰが優れていると言える。アクセスパス生成は，一般に人間の方が優れている。人間は，スキーマレベルでの最適化を行うが，動的チューニングを行うことによってＬＤＰは実現値レベルの情報を持つことができる。

謝辞

ＬＤＰ－Ｖ1.5の実現及び設計に協力して頂いているシステク社システム部長鈴木　信氏とデータベースの保守等に助力頂いた当プロジェクトの塚本　元子女史に感謝します。又，日頃御指導して頂いている当協会開発部次長小関　重美氏に感謝します。

参照文献

〔ＴＡＫＩＭ78〕

Ｔａｋｉｚａｗａ，Ｍ．，　ｅｔ　ａｌ．，”Ｒｅｓｏｕｒｃｅ　Ｉｎｔｅｇｒａｔｉｏｎ　ａｎｄ　Ｄａｔａ　Ｓｈａｒｉｎｇ　ｏｎ　Ｈｅｔｅｒｏｇｅｎｅｏｕｓ　Ｒｅｓｏｕｒｃｅ　Ｓｈａｒｉｎｇ　Ｓｙｓｔｅｍ，”Ｐｒｏｃ．ＩＣＣＣ’78，Ｋｙｏｔｏ，Ｊａｐａｎ，Ｓｅｐｔ．1978，ｐｐ．253－258.

〔ＴＡＫＩＭ79〕

Ｔａｋｉｚａｗａ，Ｍ．，　ｅｔ　ａｌ．，”Ｔｈｅ　Ｆｏｕｒ－Ｓｃｈｅｍａ　Ｃｏｎｃｅｐｔ　ａｓ　ｔｈｅ　Ｇｒｏｓｓ－Ａｒｃｈｉｔｅｃｔｕｒｅ　ｏｆ　Ｄｉｓｔｒｉｂｕｔｅｄ　Ｄａｔａｂａｓｅｓ　ａｎｄ　Ｈｅｔｅｒｏｇｅｎｅｉｔｙ　Ｐｒｏｂｌｅｍｓ，”Ｊｏｕｒｎａｌ　ｏｆ　Ｉｎｆｏｒｍａｔｉｏｎ　Ｐｒｏｃｅｓｓｉｎｇ，　ＩＰＳＪ，Ｖｏｌ．2，Ｎｏｖ．3，1979，ｐｐ．134－142.

〔TAKIM80〕
Takizawa, M., et al., "Query Translation in Distributed Database," IFIP' 80, Tokyo, Oct. 1980

〔TAKIM81〕
Takizawa, M., et al., "分散型データベースシステム（JDDBS－Ⅱ）におけるローカルデータベースプロセッサ（LDP－V1. 5）と，その評価について，" IPSJ DBMS研 25－2, 1981.

〔TAKIM82a〕
Takizawa, M., et al., "Distributed Query Processing in Local Broadcast Networks," JIPDEC- TR 82/03, 1982.

〔TAKIM82b〕
Takizawa, M., et al., "The Relational Interface System to the CODASYL Database System in Heterogeneous Distributed Database Systems," JIPDEC TR 82/04, 1982.